UDC: 628.3 https://doi.org/10.15407/jai2023.02.107

ОПТИМІЗАЦІЯ СТОКІВ З ВИКОРИСТАННЯМ НЕЙРОННОЇ МЕРЕЖІ ПРИ ОЧИЩЕННІ ПРОМИСЛОВИХ СТІЧНИХ ВОД

М. В. Матвійчук
Національний університет водного господарства та природокористування, Україна
вул. Соборна, 11, м. Рівне, 33028
myroslavmatviichuk@ukr.net
https://orcid.org/0000-0003-1669-3924

Анотація. Зростання населення планети призводить до збільшення проблеми доступу до прісної води. Основні джерела води на Землі – солонувата та морська вода. У зв'язку з водною кризою, очищення води стає надзвичайно важливим процесом і його досягнення здійснюється шляхом опріснення та різних методів водопідготовки. В цьому контексті, дослідження можливості використання нейронних мереж для покращення роботи очисних споруд є необхідним. Метою дослідження було встановлено оптимізацію та аналіз ефективності роботи очисних споруд при очищенні промислових стічних вод. Для оптимізації запропонованих моделей було використано методи м'яких обчислень. У цьому дослідженні були визначені точні результати застосування нейронної мережі за допомогою аналітичного та порівняльного підходів. Очищення всіх стічних вод і відходів, що утворюються в очисній промисловості, включає ряд процесів, включаючи повітряну флотацію, хімічну коагуляцію, відстоювання і біологічне очищення з використанням повністю змішаного активного мулу. Розглядалися різні функції навчання, включаючи штучні нейронні мережі (ШНМ) з прямим поширенням, такі як багатошаровий персептрон (MLP), каскадні ШНМ з прямим поширенням та моделі регресії з опорними векторами (SVR). Процес навчання включає використання алгоритмів оптимізації Левенберга-Марквардта та послідовного мінімуму. У статті також наведено графічні зображення, що ілюструють різні типи забруднювачів, витрати, пов'язані з очисними спорудами, та зміни кольору стічних вод, що спостерігаються після процесу очищення. Отримані результати демонструють високий ступінь подібності між прогнозованими та експериментальними даними, що підкреслює ефективність ANN-моделі зі зворотним розповсюдженням для точних прогнозів. Крім того, інтеграція машинного навчання у виробництво миючих засобів може бути надзвичайно ефективною, сприяючи ефективному та сталому використанню водних ресурсів. Загалом, стаття надає цінні висновки щодо використання машинного навчання для розв'язання проблеми дефіциту прісної води.

Ключові слова: очисні споруди, модель, ресурси, регресія опорних векторів, моделювання.

OPTIMIZATION OF EFFLUENTS USING A NEURAL NETWORK IN THE TREATMENT OF INDUSTRIAL WASTEWATER

M. Matviichuk
National University of Water and Environmental Engineering, Ukraine
11, Soborna Str., Rivne, 33028
myroslavmatviichuk@ukr.net
https://orcid.org/0000-0003-1669-3924

Abstract. The growth of the planet's population leads to an increase in the problem of access to fresh water. The main sources of water on Earth are brackish and sea water. In connection with the water crisis, water purification becomes an extremely important process, and its achievement is carried out through desalination and various methods of water treatment. In this context, research into the possibility of using neural networks to improve the operation of sewage treatment plants is necessary. The purpose of the research was to optimize and analyze the efficiency of the work of treatment facilities in the treatment of industrial wastewater. Soft computing methods were used to optimize the proposed models. In this study, the exact results of the application of the neural network were determined using analytical and comparative approaches. Treatment of all wastewater and waste generated in the treatment industry involves a number of processes including air flotation, chemical coagulation, settling and biological treatment using fully mixed activated sludge. Various learning functions have been considered, including forward-propagation artificial neural networks (ANNs) such as multilayer perceptron (MLP), cascaded forward-propagation ANNs, and support vector regression (SVR) models. The learning process includes the use of Levenberg-Marquardt optimization algorithms and sequential minimum. The article also provides graphical images illustrating the different types of pollutants, the costs associated with treatment plants, and the color changes in wastewater observed after the treatment process. The obtained results show a high degree of similarity between the predicted and experimental data, which emphasizes the effectiveness of the backpropagation ANN model for accurate predictions. In addition, the integration of machine learning into the production of detergents

can be extremely effective in promoting the efficient and sustainable use of water resources. Overall, the paper provides valuable insights into the use of machine learning to address freshwater scarcity.

Keywords: treatment facilities, model, resources, regression of support vectors, modeling.

Вступ

Необхідність моделювання концентрацій та характеристик стічних вод у сфері водопідготовки відкриває шлях до підвищення ефективності очисних споруд. Проблема недостатнього водопостачання є найважливішою в багатьох країнах, призводячи щодня до смерті сотень людей у слаборозвинених регіонах через недостатнє водопостачання та погані санітарні умови. Водопостачання стає проблемою навіть у багатих країнах, де відпрацьовані води стають поширеним явищем. Неефективні септичні системи та системи очищення стічних вод призводять до забруднення озер, річок та підземних вод [1]. Ці стоки відомі як стічні води, але можна використати та відновити значну частину цих вод для подальшого використання. У зв'язку з глобальною водною кризою та передбачуваною нестачею води у майбутньому, стічні води, що виходять з промислових підприємств, швидко стають безцінним альтернативним ресурсом придатної для використання води.

Постановка проблеми

Сьогодні належне поводження з промисловими стічними водами становить велику проблему, оскільки воно включає різні трудомісткі та дорогі етапи. Розрахунок онлайн-значень якості компонентів у стічних водах під час їх очищення є великим викликом. Промисловість, що використовує мийні засоби, вимагає забезпечення якості та ефективності процесу. Біохімічне споживання кисню, хімічне споживання кисню, загальна органічна речовина, загальні розчинені тверді речовини, рівень водневого потенціалу (pH) та органічні речовини загального вуглецю – всі ці забруднюючі речовини мають важливе значення для ефективної та надійної роботи очисних споруд, тому їх потрібно безпомилково та своєчасно вимірювати. Однак впровадження пристроїв для онлайн-моніторингу в області очищення стічних вод є складним і вимагає значних фінансових витрат. У таких умовах м'які обчислення стають популярним та зручним інструментом для розробки моделей. Застосування методів м'яких обчислень, таких як нейронні мережі, нечіткі множини, машини опорних векторів, дерева регресії тощо, стає популярним у різних галузях промисловості з різноманітними застосуваннями завдяки їх простоті та здатності до надійного прогнозування значень.

Аналіз останніх досліджень і публікацій

Зважаючи на актуальну проблему та необхідність удосконалення процесу очищення промислових стічних вод, дослідники проводили експерименти та аналізи, аби знайти необхідний варіант розв’язання проблеми. V. L. Filipchuk et al. [2] дослідили оновлені технологічно-технічні засоби для очищення виробничих стічних вод від важких металів, які містять органічні та неорганічні домішки різних фазово-дисперсних станів. В результаті проведеної розробки були створені сучасні системи очищення багатокомпонентних металовмісних стічних вод, що використовують автоматизоване керування pH і Eh з використанням мікропроцесорних засобів та передових інформаційних технологій.

M. M. Tymkiv [3] досліджувала оптимізацію мережі гідрогеоекологічного моніторингу за допомогою геоінформаційного і геостатистичного аналізу. Дослідниця вивчала ряди даних з пропусками та розрахувала екологічні ризики для окремих суббасейнів, а також побудувала карту абсолютних рівнів підземних вод на основі моніторингових досліджень для досліджень рівнів підземних вод та прогнозування мережі гідрогеологічного та екологічного моніторингу.

V. M. Shtepa [4] досліджував зменшення техногенного навантаження на навколишнє середовище через поліпшення управління екологічною безпекою технологій очищення стічних вод на промислових об'єктах. У дослідженні були враховані ризики надзвичайних ситуацій та вимоги енергоефективності. Застосування віртуальної міри енергоефективності водоочищення дозволило створити системи промислового водоочищення з об'єктно-орієнтованим підходом до управління екологічною безпекою та потенційними надзвичайними ситуаціями.

L. M. Predzymirska [5] розробила заходи для підвищення екологічної безпеки промислових виробництв через створення кавітаційної технології очищення стічних вод від органічних і біологічних забруднень. Введення азоту в оброблюване середовище підвищує кількість зародків кавітації в рідині, що збільшує інтенсивність кавітаційного поля та ефективність очищення.

В експерименті дослідників Y. Xie et al. [6] проводились спроби покращення процесу прогнозування якості роботи очисних споруд при очищенні стічних вод із використанням нейронної мережі та алгоритму оптимізації. Вченими розроблено модель штучного інтелекту ML на основі FFNN і GA для точного та ефективного прогнозування якості стічних вод у реальному часі в очисних спорудах. Ця модель може вирішувати завдання з видалення забруднюючих речовин і реагування на них, забезпечуючи безпечну експлуатацію споруд.

Досліджень інших вчених недостатньо, аби почати практичне використання нейронної мережі для оптимізації очищення промислових стічних вод. Це пов’язано з тим, що з використанням конкретних параметрів не проводились подібні експерименти, а також не було досягнуто подібного результату за допомогою інших методів. Саме тому необхідно було продовжити вивчення цієї теми та провести ще одне дослідження, яке допомогло визначити чіткий метод використання нейронних мереж для використання в очищенні промислових стічних вод.

Мета дослідження

Основні цілі дослідження оптимізації очищення промислових стічних вод з використанням нейронних мереж: підвищення ефективності очищення та зменшення забруднення навколишнього середовища; зниження витрат на очищення шляхом оптимального використання ресурсів; дотримання стандартів щодо якості очищення стічних вод; зменшення негативного впливу на природне середовище, збереження водних ресурсів; розробка оптимального методу очищення з використанням нейронних мереж, який буде проводити детальний та чіткий аналіз показників.

Виклад основного матеріалу

У дослідженні було проведено оцінку ефективності роботи очисних споруд шляхом аналізу очищених стічних вод, які були отримані з водопровідно-каналізаційного господарства. Дослідження включало аналіз різних параметрів якості води, зокрема pH, температури, кольору, запаху, хімічного споживання кисню (ХСК), біохімічного споживання кисню (БСК), загального вмісту завислих речовин (TSS), загального вмісту розчинених твердих речовин (TDS) та нафтопродуктів і мастил (O&G). Ці параметри були використані для оцінки якості води та ефективності роботи очисних споруд. Дослідження було проведено для оцінки ефективності роботи очисних споруд при очищенні промислових стічних вод. Основною метою дослідження було визначити якість води після проходження через очисні споруди та оцінити, наскільки ефективно вони видаляють забруднюючі речовини. Дослідження також дозволяє виявити можливі проблеми або недоліки в роботі очисних споруд. Якщо якість очищеної води не задовольняє встановлені стандарти, то це свідчить про неефективність чи несправність очисних систем, що вимагає подальшого вдосконалення або відновлення.

Також у статті використовувались дослідницькі методи, а саме аналітичний та порівняльний. Аналітичний метод використовувався для розгляду та оцінки різних параметрів та властивостей стічних вод, які були отримані з промислових джерел. Порівняльний метод був використаний для зіставлення ефективності різних підходів та технологій очищення стічних вод. Цей метод включав порівняння результатів досліджень, проведених на різних очисних спорудах або з використанням різних методик очищення.

У цьому дослідженні використовувались два різних типи ШНМ для прогнозування значень параметрів стічних вод. Один з них – багатошаровий персептрон (MLP), який є окремим випадком нейронної мережі прямого поширення (FFNN), що є дуже популярним типом ШНМ. Простіша конструкція нейронної мережі прямого поширення має переваги машинного навчання. Деякі мережі Feedforward можуть працювати самостійно, з невеликою взаємодією для забезпечення модерації. При виконанні складних завдань мережа потребує співпраці кількох нейронів. Нейронна мережа спрощує обробку та аналіз нелінійних даних і допомагає уникнути проблем прийняття рішень. У цьому типі мережі передача інформації відбувається односторонньо, лише у напрямку вперед. Виходи нейронів прихованого шару послідовно стають входами вихідних нейронів, де вони піддаються різним змінам.

Це дослідження також використовує правило керованого навчання, де вхідні дані та бажані результати використовуються для прогнозування. Прогнозовані значення порівнюються з бажаними вихідними значеннями параметрів і на основі цього порівняння обчислюється величина похибки. Після цього ваги і зміщення коригуються з метою зменшення похибок і процес повторюється. У дослідженні використовувались наступні формули:

1.Рівняння для активації “Purelin” (1):

$$f(n) = n. \tag{1}$$

2.Проведення розрахунку RMSE (2):

$$RMSE = \sqrt{\frac{1}{m}\sum_{i=1}^{m} (y_{act_i} - y_{pred_i})^2}, \tag{2}$$

де m – кількість спостережень або даних, для яких проводилось прогнозування;
i – індекс, який використовується для ітерації через кожне спостереження;
y_{act_i} – фактичне значення спостереження i-го випадку;
y_{pred_i} – прогнозоване значення для i-го випадку.

3.Знаходження коефіцієнта детермінації (3):

$$R^2 = 1 - \frac{\sum_{i=1}^{m} (y_{act_i} - y_{pred_i})^2}{\sum_{i=1}^{m} y_{act_1}^2}. \tag{3}$$

4.Визначення середньої абсолютної помилки (4):

$$MAE = \frac{1}{m}\sum_{i=1}^{m} \left|y_{act_i} - y_{pred_i}\right|. \tag{4}$$

Отримані дані можуть бути використані для подальших досліджень і розробки нових методів очищення, вдосконалення існуючих технологій та створення більш ефективних очисних споруд.

Оптимізація роботи очисних споруд підкреслює важливість точного моделювання специфічних концентрацій і характеристик, які зазвичай зустрічаються у водоочисній промисловості. Дефіцит води широко визнаний критичною проблемою в багатьох країнах [7]. У менш розвинених країнах недостатнє водопостачання та неадекватна санітарія призводять до численних щоденних смертей. І навпаки, у заможних країнах поширене марнотратство води та недостатня кількість септиків і систем очищення стічних вод призводять до забруднення озер, річок і підземних вод. Вода, яка залишається після використання, зазвичай називається стічними водами, хоча існують можливості переробляти і

відновлювати значну її частину для подальшого використання.

У світлі триваючої глобальної водної кризи та прогнозованих майбутніх рівнів дефіциту води, скидання стічних вод з промислових об'єктів швидко набуває визнання як цінне альтернативне джерело придатної для використання води [8]. Викид відходів у навколишнє середовище через воду є критичною проблемою для промислових підприємств. Забруднюючі речовини, присутні у стічних водах, можуть становити ризики для екосистем, здоров'я людей та всіх форм життя. Тому ефективне видалення забруднюючих речовин зі стічних вод перед їхнім потраплянням у навколишнє середовище набуває першочергового значення. Стічні води містять різні типи забруднювачів, зокрема:

1. Водневий потенціал (pH) вимірює кислотність або лужність стічної води. Рівень pH може впливати на ефективність обробки та може бути коригований для досягнення оптимальних умов.

2. Загальний вміст завислих речовин (TSS) вказує на кількість твердих частинок або матеріалів, які перебувають у воді. Це можуть бути пісок, глина, органічні речовини тощо.

3. Загальний вміст розчинених твердих речовин (TDS) відображає кількість речовин, розчинених у воді. Це можуть бути солі, метали, хімічні речовини та інші розчинені речовини.

4. Нафтопродукти та мастила (O&G) представляють нафтопохідні речовини, які

5. можуть бути присутні у стічних водах від промислових процесів або від стічних вод автотранспорту.

6. Біохімічне споживання кисню (БСК) та хімічне споживання кисню (ХСК) вказують на кількість кисню, який використовується для біологічного або хімічного розкладу органічних речовин у воді. Це допомагає визначити органічну забрудненість стічних вод [9].

Забруднюючі речовини, що містяться у стічних водах, можна розділити на різні типи, як показано на рис. 1. З точки зору характеру і ступеня видалення забруднювачів, було запропоновано і застосовується кілька методів очищення води. Оцінка якості стічних вод включає оцінку їх хімічних, фізичних та біологічних характеристик. Хімічні характеристики оцінюють концентрацію різних речовин у стічних водах, таких як розчинені метали, хімічні сполуки та інші забруднюючі речовини. Фізичні характеристики включають такі параметри, як колір, ступінь мутності та температуру стічної води. Біологічні характеристики визначають наявність та концентрацію бактерій, водних водоростей та інших організмів, які можуть бути присутні у стічних водах.

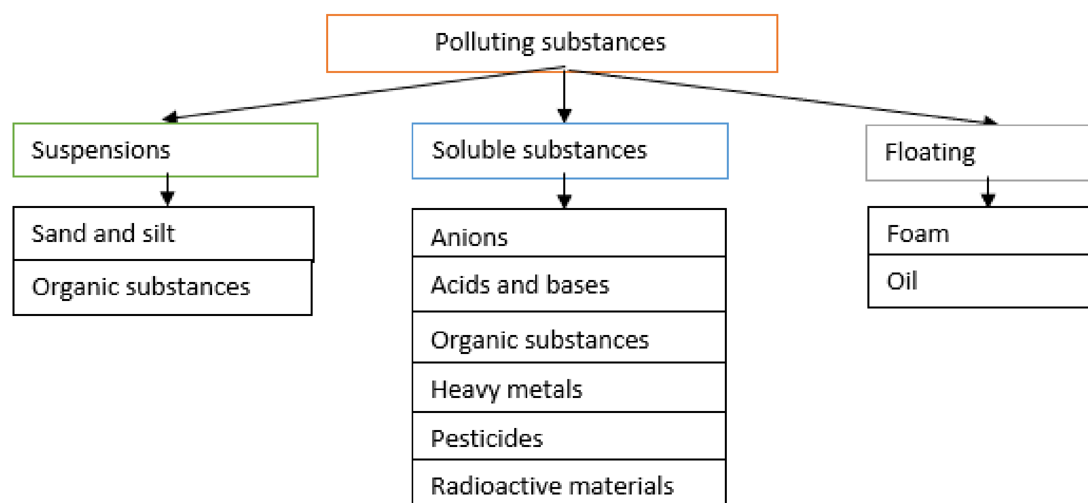


Рис. 1. Типи забруднюючих речовин, присутніх у стічних водах (джерело: O. B. Akpor et al. [10])

Моделювання конкретних концентрацій і характеристик стічних вод допомагає визначити оптимальні методи очищення та забезпечити ефективне видалення забруднюючих речовин. Це може включати фізичні процеси, такі як відстійники, фільтрація або аеробні та анаеробні процеси біологічного очищення. Для досягнення заданих стандартів якості води важливо враховувати конкретні потреби та характеристики стічних вод, що обробляються.

У машинному навчанні (ML) користувачам не потрібно мати детальне розуміння внутрішньої реалізації. Згідно з цією концепцією, початкові набори даних можуть служити як навчальні вибірки для постійного оновлення моделей. Фреймворк використовує методи машинного навчання для створення остаточної прогнозуючої моделі. Існує багато різних алгоритмів машинного навчання з різними теоретичними основами для навчання моделей. Вибір найкращого алгоритму або універсального методу навчання моделей є складним завданням. У даному дослідженні для налаштування моделі були застосовані два методи м'яких обчислень – MLP та SVR [11]. Модель, яка демонструвала найкращу відповідність, була включена в структуру для досягнення кращих результатів.

Оптимізація штучних нейронних мереж (ШНМ) має вирішальне значення для підвищення продуктивності мережі. У цьому дослідженні було використано функцію активації “Purelin” для підвищення точності прогнозування даних за допомогою різних методів навчання ШНМ [12]. Функція активації “Purelin” може бути математично визначена за допомогою рівняння (1).

Зовнішній діапазон функції активації “Purelin” складає [+1, -1]. На рис. 2 графічно показано символ цієї функції. У даному дослідженні використовувалась ця функція активації для нормалізації вихідних даних, з метою забезпечити їх значення в межах даного діапазону. Для оптимізації мережі були використані дві моделі штучних нейронних мереж з різними функціями навчання. Для цього оптимізаційного дослідження було використано алгоритм навчання зворотного поширення помилки Левенберга-Марквардта (LM) для тренування мережевих моделей з 5 прихованими шарами для кожної з навчальних функцій.

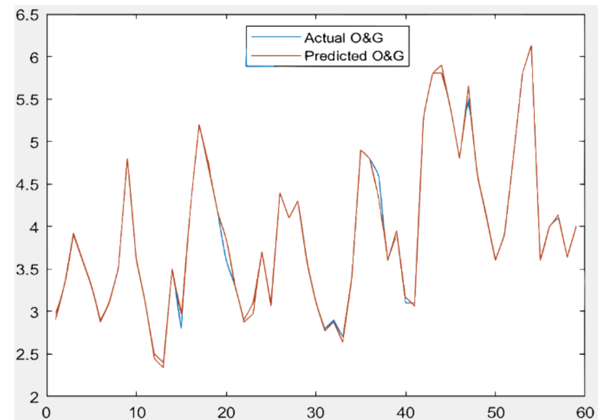


Рис. 2. Фактичний та прогнозований результат через CFNN (джерело: Q. Xinyi [13])

Алгоритм LM виявився найефективнішим і мав найменшу кількість ітерацій серед різних комбінацій функцій активації для апроксимації функцій з менш ніж сотнею поновлюваних ваг. Інші алгоритми зазвичай вимагають більше ітерацій, ніж алгоритм LM, хоча це саме той випадок, який розглядається в цьому дослідженні. Практично, алгоритм LM часто показує кращі результати оптимізації для різних типів задач порівняно з іншими алгоритмами. Усі ці алгоритми відомі своєю швидкою збіжністю на різних типах задач. Оцінка моделей проводиться з використанням тестових даних, порівнюючи отримані результати з прогнозованими значеннями. Крім того, для оцінки ефективності та точності моделей прогнозування використовуються різні метрики, зокрема середньоквадратична помилка (RMSE) та коефіцієнт детермінації (R^2). Розрахунок RMSE можна виконати за допомогою рівняння (2).

Детермінаційний коефіцієнт (R^2) визначається за допомогою рівняння (3) і використовується для оцінки узгодженості між очікуваними та прогнозованими значеннями. Крім того, для оцінки експозиції та продуктивності

прогнозованих моделей застосовується середня абсолютна помилка (MAE), яка визначається рівнянням (4).

У цій роботі досліджується якість прогнозованих моделей, використовуючи ці метри, що дозволяють оцінити їхню точність та надійність. Враховуючи характеристики швидкої збіжності та продуктивності різних типів задач, алгоритми оптимізації, використані в цьому дослідженні, мають відповідні переваги та обмеження. Алгоритм БП Левенберга-Марквардта (LM) є особливо ефективним для апроксимації функцій та забезпечує найкращі результати для даного контексту, оскільки він збігається з меншою кількістю ітерацій порівняно з іншими алгоритмами [14]. Однак, відбувається ітеративна оптимізація моделей, що може зайняти певний час та ресурси.

Під час проведення досліджень важливо враховувати як оцінку точності моделей, так і їхню ефективність. Отримані результати, такі як значення RMSE, R^2 та MAE, можуть бути використані для порівняння різних моделей та оцінки їх відповідності передбачуваним і очікуваним значенням. Модель з меншими значеннями RMSE та MAE відображає вищу точність прогнозування даних. У той же час, модель, де значення R^2 наближається до 1, демонструє більшу узгодженість з даними.

Для оцінки ефективності побудованих моделей використовуються такі показники, як коефіцієнт кореляції (R) і середньоквадратична помилка (MSE). Оптимальною вважається модель з максимальним значенням R і мінімальним значенням MSE. Ці параметри допомагають визначити, наскільки точно модель прогнозує дані.

У результаті було сформульовано дві різні моделі: штучні нейронні мережі (ШНМ) та моделі регресії з опорними векторами (SVR). Для підвищення точності прогнозування для навчання штучних нейронних мереж було використано алгоритм Левенберга-Марквардта (LM). У процесі навчання було використано функцію навчання TRAINLM та функцію адаптивного навчання LEARNGDM [15]. Мережева модель була створена шляхом налаштування ваг та зсувів нейронів, які з'єднують різні шари мережі. Кількість прихованих нейронів у прихованому шарі було визначено шляхом ітеративного експерименту, оцінюючи продуктивність моделі для різних кількостей прихованих нейронів.

Статистичні дані ефективності моделей штучних нейронних мереж для прогнозування різних показників якості стічних вод, таких як БСК, ХСК, TSS, TDS та O&G, були розраховані окремо для кожного показника. Це дозволило адекватно оцінити вплив кожного параметра і отримати значення для стічних вод. Таким чином, розглядалися та порівнювалися різні моделі залежно від їхньої ефективності у прогнозуванні різних показників якості стічних вод.

Для оцінки продуктивності розроблених моделей використовуються значення, які порівнюються з передбаченими результатами, отриманими за допомогою двох алгоритмів – штучних нейронних мереж (ANN) і алгоритму SVR [16]. Під час оцінки роботи моделей також враховуються похибки, що виникають при обчисленні відхилень між прогнозованими та цільовими результатами. Для оцінки точності роботи моделей проводиться візуальний огляд та аналіз низьких значень похибок.

Моделювання з використанням методів навчання нейронних мереж дає регресійні значення. В усіх випадках значення коефіцієнта кореляції (R) дуже близьке до 1, що свідчить про гарний дизайн моделі з точки зору параметрів. Помилки для кожної моделі також враховуються, і цей метод надає важливі дані для побудови моделей.

Під час моделювання з використанням методу CFNN були отримані значення регресії, і всі значення коефіцієнта кореляції (R) регресійних моделей були близькими до 1 [17]. Це свідчить про високу якість моделей, що були навчені за допомогою цього методу. Таким чином, використання цього нового підходу до машинного навчання дозволило

успішно прогнозувати дані та створювати ефективні моделі (рис. 3-5).

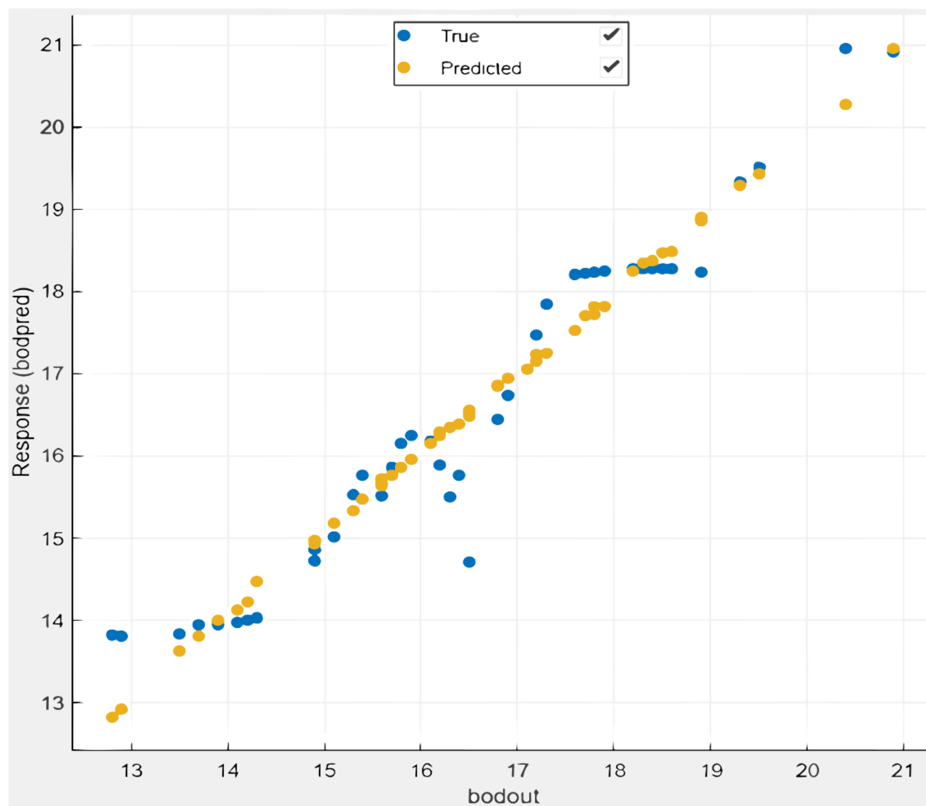


Рис. 3. Фактичний та прогнозований результат БСК через SVR (джерело: D. K. Jana et al. [18])

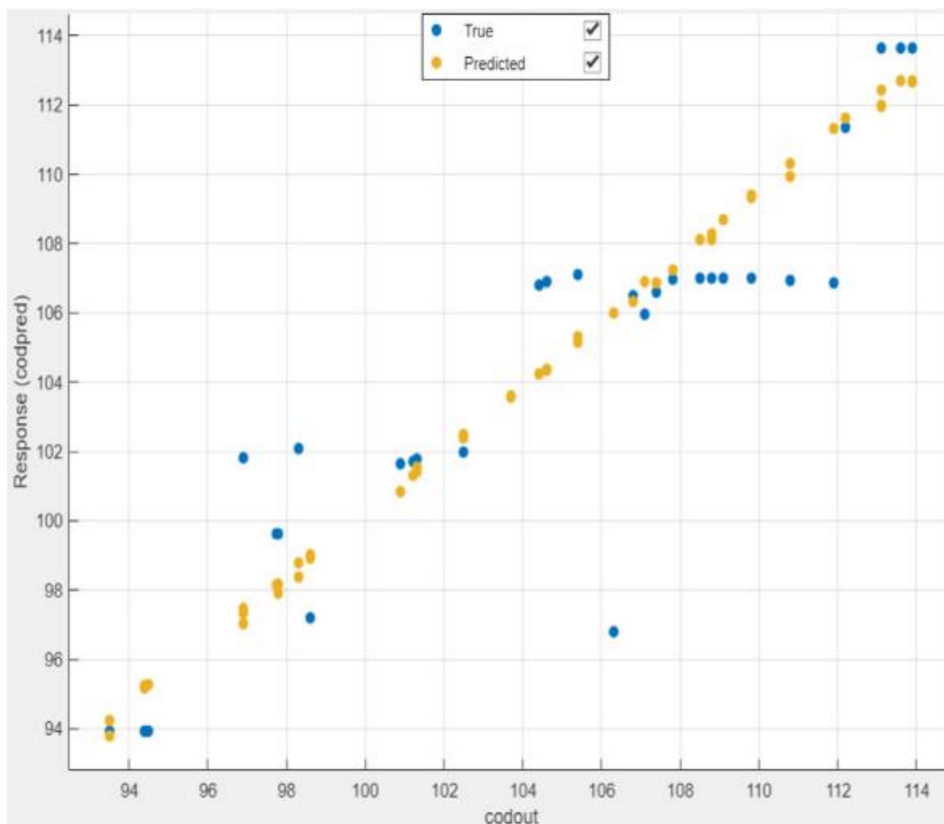


Рис. 4. Фактичний та прогнозований результат ХСК через SVR (джерело: D. K. Jana et al. [18])

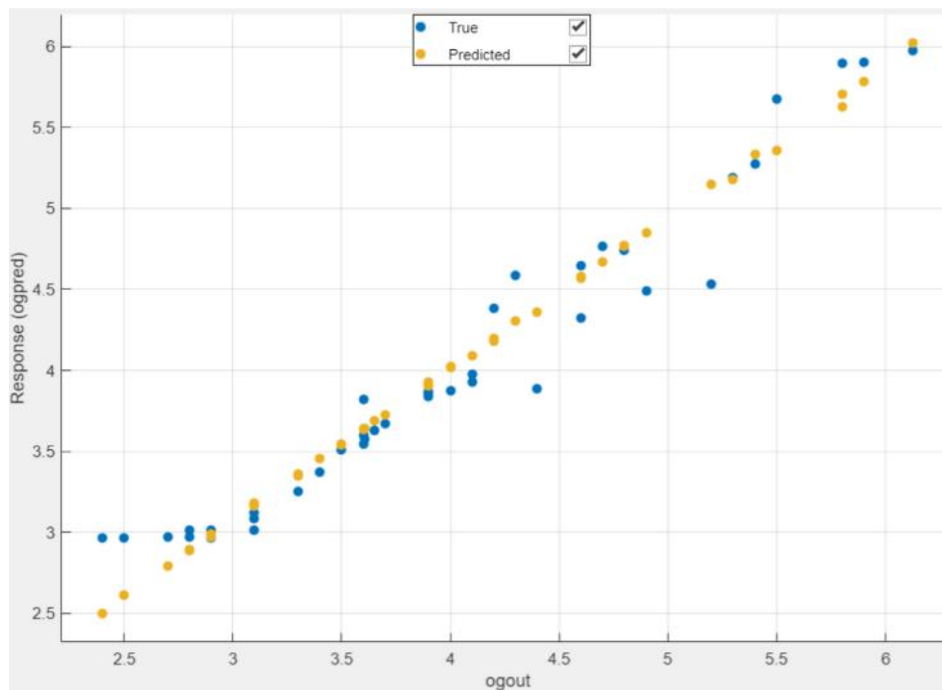


Рис. 5. Фактичний та прогнозований результат TSS через SVR (джерело: D. K. Jana et al. [18])

Порівняння вихідних значень стічних вод з прогнозованими значеннями параметрів БСК, ХСК, та TSS, отриманими за допомогою алгоритму SVR, зображено на рис. 3, 4 та 5, відповідно. Візуальний огляд та менші значення похибок свідчать про успішну розробку моделі. Коефіцієнт детермінації (R^2), середня абсолютна похибка (MAE), середня квадратична похибка (MSE) та середньоквадратична похибка (RMSE) були розраховані для кожного параметра та методу навчання. Представлено комплексний порівняльний аналіз цих результатів разом з оцінкою продуктивності моделі для кожного типу вхідних-вихідних даних.

Таблиця 1 містить стислий огляд результатів моніторингу. Цей регресійний аналіз досліджує відповідність між очікуваними та виміряними значеннями даних. Результати показують, що всі методи навчання, використані в цьому дослідженні, демонструють високу точність у прогнозуванні даних. Однак, якщо порівнювати, то штучна нейронна мережа (ШНМ) демонструє вищу ефективність з точки зору продуктивності моделі порівняно з методом регресії на основі опорних векторів (SVR).

На рис. 6 представлено графічне порівняння результатів моніторингу для всіх параметрів, що були взяті з відкритих даних інших досліджень [18]. Графічний аналіз однозначно підтверджує, що модель ANN є найефективнішою у досягненні високої відповідності між даними для всіх параметрів. Залежно від наявних даних, метод навчання штучних нейронних мереж може бути змінений, щоб забезпечити оптимальну відповідність між виміряними параметрами та прогнозованими значеннями.

Отже, засновуючись на проведених дослідженнях, можна зробити висновок, що всі використані методи навчання дали високоякісні прогнозовані дані, проте ANN виявилася найефективнішою з точки зору продуктивності моделі. Представлені графіки та аналіз показують, що розроблені моделі забезпечують точність і відповідність даним. Враховуючи характеристики доступних даних, може бути вибраний відповідний метод навчання для найкращих результатів.

Таблиця 1. Результати моніторингу (джерело: K. Sharma [19])

Предмет моніторингу	Метод	R^2	MAE	MSE	RMSE
БСК	Пряме зворотне розповсюдження (MLP)	0.99914	0.33251	0.23816	0.48801
	Каскадне зворотне поширення	0.99845	0.21291	0.42838	0.65451
	SVR	0.92	0.34729	0.24948	0.49948
ХСК	Пряме зворотне розповсюдження (MLP)	0.99949	1.60832	5.55047	2.35595
	Каскадне зворотне поширення	0.99999	0.006	0.00031	0.01771
	SVR	0.85	1.5873	5.0358	2.2441
TSS	Пряме зворотне розповсюдження (MLP)	0.99919	0.46111	0.36018	0.60015
	Каскадне зворотне поширення	0.99994	0.11892	0.02743	0.16562
	SVR	0.89	0.38755	0.29855	0.5464
TDS	Пряме зворотне розповсюдження (MLP)	0.99997	2.85359	36.30566	6.02542
	Каскадне зворотне поширення	0.99992	8.00436	110.00656	10.48841
	SVR	1	6.1056	76.129	8.7252
O&G	Пряме зворотне розповсюдження (MLP)	0.9978	0.12155	0.03571	0.18898
	Каскадне зворотне поширення	0.99973	0.03509	0.00433	0.06582
	SVR	0.96	0.12371	0.03133	0.17701

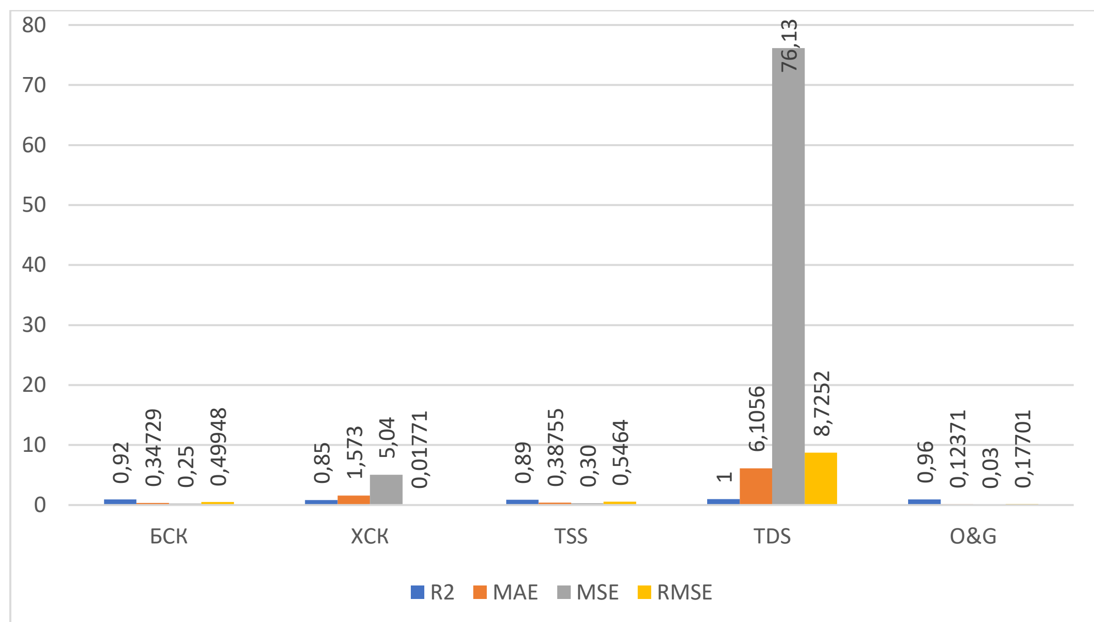


Рис. 6. Графічне представлення виміряних значень різних параметрів стічних вод

Враховуючи результати проведеного дослідження, можна сказати, що використання нейронної мережі може значно покращити показники виміру якості стічних вод та оцінки продуктивності роботи очисних споруд. Також додатково варто проаналізувати інші дані деяких вчених, які також вивчали особливості використання нейронних мереж у даній сфері.

Дослідники N. D. Singh et al. [20] провели експеримент, спрямований на розробку моделі очищення стічних вод з використанням штучного інтелекту. У своїй статті вони продемонстрували перевагу прогнозування ХСК (хімічної споживаності кисню) за допомогою ШНМ (штучних нейронних мереж) порівняно зі стандартним математичним моделюванням. Дослідники використали штучні нейронні мережі, які є одним з основних інструментів штучного інтелекту, для прогнозування ХСК у процесі очищення стічних вод. Вони порівняли результати прогнозування, отримані за допомогою ШНМ, з результатами, отриманими з використанням стандартної математичної моделі. Виявилося, що

використання ШНМ у моделюванні прогнозу ХСК призвело до кращих результатів порівняно зі стандартною математичною моделлю. Це означає, що штучний інтелект може бути ефективним інструментом для прогнозування і контролю якості очищення стічних вод. Хоча дослідження, спрямоване на розробку моделі очищення стічних вод з використанням штучного інтелекту, може мати свої переваги, воно також має деякі недоліки, які можна врахувати. Деякі з таких недоліків включають: для ефективного навчання моделей штучного інтелекту необхідні великі обсяги якісних та репрезентативних даних; вибір правильного алгоритму та архітектури штучної нейронної мережі є важливою задачею при розробці моделі очищення стічних вод; штучні нейронні мережі часто вважаються "чорними скриньками", оскільки їх рішення можуть бути складними для пояснення; використання штучного інтелекту у сфері очищення стічних вод також викликає питання етики та безпеки.

S. Pezhhanfar et al. [21] провели дослідження, що включало застосування нейронних мереж, ізотерм та кінетичних вимірювань для очищення стічних вод з використанням обрізаного матеріалу *Populus alba*. Це дослідження виявило, що обрізана тирса твердої деревини дерева *Populus alba* має високу адсорбційну здатність, яка може бути використана в процедурах очищення стічних вод. Аналіз отриманих даних ізотермічних досліджень показав, що процес адсорбції найкраще пояснюється моделлю ізотерми Ленгмюра з високим коефіцієнтом кореляції. Крім того, під час проведення дослідження використовувалась нейронна ANN-модель, яка змогла провести додатковий аналіз отриманих результатів. Проте, було виділено декілька недоліків, а саме: обмеженість у використанні аналогових речовин для очищення стічних вод, можливість варіацій результатів очищення в залежності від умов проведення очистки, економічні витрати досить високі для постійного використання під час очищення води, у дослідженні не враховані негативні впливи на навколишнє середовище тощо. Враховуючи ці недоліки, дослідження вносять важливий внесок у розуміння можливостей використання штучного матеріалу для очищення стічних вод. Для подальшого розвитку цієї галузі дослідники можуть зосередитися на вирішенні виявлених недоліків та розширенні можливостей застосування штучного матеріалу для очищення стічних вод.

B. Yang et al. [22] провели дослідження, використовуючи глибоке навчання для прогнозування якості стічних вод у водно-болотних угіддях. Використовуючи нейронну мережу глибокого навчання, вони змогли успішно прогнозувати якість стічних вод наступного дня для великомасштабних комплексів водно-болотних угідь та встановити зв'язок між зібраними наборами даних з різних джерел і якістю стічних вод. Порівнявши чотири моделі для прогнозування трьох показників якості стічних вод, дослідники дійшли кількох висновків. У випадках, коли вхідні дані демонструють значні коливання, метод ковзного середнього може ефективно усунути високочастотний шум, тим самим підвищуючи точність прогнозування, особливо в реальних великомасштабних додатках. У порівнянні з методом множинної лінійної регресії (MLR), нейронною мережею прямого поширення та нейронною мережею, оптимізованою за допомогою генетичного алгоритму, нейронна мережа глибокого навчання LSTM продемонструвала чудову ефективність прогнозування для даних часових рядів, таких як якість води. Використовуючи свою здатність враховувати попередні результати навчання, мережа LSTM виявилася придатною для точного прогнозування якості води. Цей підхід дозволяє робити швидкі прогнози в реальних сценаріях, використовуючи великий набір легкодоступних показників якості води. Крім того, використання нейронної мережі LSTM усуває необхідність проведення дорогих експериментів для отримання різних параметрів для моделювання КС (кінетичної схеми). Отже, це дослідження

висвітлює потенціал методів глибокого навчання, зокрема LSTM, у сфері прогнозування якості стічних вод, пропонуючи багатообіцяючі перспективи для майбутніх застосувань. Ці висновки підкреслюють важливість врахування змінних факторів, використання відповідних алгоритмів та збору якісних даних для поліпшення точності та ефективності прогнозування. Далі дослідження в цій галузі можуть сприяти розробці більш точних та надійних моделей для управління якістю стічних вод і збереження водних ресурсів.

Проведене дослідження показало, що модель ANN демонструє високу точність та надійність у визначенні оптимальних параметрів для очищення промислових стічних вод. Вона може враховувати багато факторів, таких як фізико-хімічні характеристики стічних вод, режими роботи очисних споруд, об'ємні навантаження та інші вхідні параметри. Завдяки здатності нейронних мереж до самонавчання та адаптації до змінних умов, модель ANN може оптимізувати процес очищення стічних вод шляхом автоматичного вибору оптимальних налаштувань системи. Це дозволяє досягати ефективного видалення забруднюючих речовин та знижувати експлуатаційні витрати. Крім того, модель ANN забезпечує широкий спектр можливостей для аналізу та прогнозування впливу промислових стічних вод на довкілля та екосистеми. Вона дозволяє оцінити ризики забруднення водних ресурсів та визначити оптимальні стратегії для зменшення негативного впливу на навколишнє середовище.

У цій темі можливі подальші дослідження, спрямовані на розширення знань і покращення ефективності очищення стічних вод. Ось декілька напрямків досліджень, які можуть бути корисними: вивчення і розробка нових методів очищення стічних вод, включаючи високоефективні фільтраційні системи, процеси відновлення ресурсів та інноваційні методи обробки стічних вод; дослідження можуть бути спрямовані на використання нових матеріалів для покращення очищення стічних вод, наприклад, впровадження наноматеріалів для видалення забруднюючих речовин або розробка спеціальних мембран для фільтрації; поліпшення ефективності та оптимізацію різних процесів очищення стічних вод, що включає оптимізацію режимів роботи, використання розумних систем керування, моделювання та прогнозування процесів; дослідження можливостей використання альтернативних джерел води, таких як дощова вода, відходи харчової промисловості або відпрацьовані води, для подальшого використання, що сприятиме економії прісної води та зменшенню використання водних ресурсів; розробка нових методів аналізу та моніторингу стічних вод, що може включати використання сучасних аналітичних інструментів, сенсорів та датчиків для визначення конкретних характеристик і забруднюючих речовин у стічних водах; з урахуванням зростання кліматичних змін, дослідження можуть зосередитися на вивченні впливу змін клімату на якість та характеристики стічних вод; розробка ефективних систем повторного використання та утилізації стічних вод, що включає вивчення технологій очищення стічних вод для подальшого використання у промислових процесах, сільському господарстві, а також розробку методів обробки стічних вод для отримання ресурсів, таких як енергія, добрива або питна вода.

Висновки

Це дослідження було зосереджене на вивченні управління стічними водами, що утворюються на підприємствах. Для розв'язання проблеми утилізації стічних вод та відходів виробництва миючих засобів було досліджено різні методи очищення. Ці методи включають повітряну флотацію, хімічну коагуляцію, відстоювання та комплексний підхід до біологічного очищення з використанням ретельно перемішаного активного мулу. У цьому дослідженні використовувався підхід SVR для прогнозування параметрів стічних вод. Ці параметри включають

хімічне споживання кисню (ХСК), біологічне споживання кисню (БСК), загальну кількість розчинених речовин (TDS), загальну кількість завислих речовин (TSS), а також органічні речовини і мул (O&G). Для цього дослідження використовувався набір даних, що охоплює шестимісячний період.

Моделі штучних нейронних мереж (ANN) та алгоритму SVR були піддані оптимізації за допомогою відповідних методів. Результати свідчать, що більш точні прогнози можна отримати при наявності більшої кількості вхідних даних. Зокрема, модель, яка використовує метод прямого зворотного поширення (MLP), показала найкращі результати (значення R^2 = 0.99, MAE = 0.33, MSE = 0.24 і RMSE = 0.49) для показника БСК порівняно з іншими методами машинного навчання. Отримані моделі можуть застосовуватися для оптимізації роботи очисних споруд у наступних дослідженнях.

Найкраща модель показала високу кореляцію (r = 0.99). Порівнюючи ці результати з попередніми дослідженнями, було помічено, що прогнозовані результати перевищили результати попередніх досліджень (Ņ = 0.74), незважаючи на використання мінімальних параметрів. Це підтверджує валідність і достовірність отриманих даних та практичну цінність моделі з інженерними рекомендаціями. Валідність моделі, розробленої в цьому дослідженні, буде перевірено в довгострокових прогнозах, коли стануть доступними додаткові дані.

Запропонований метод може бути розширений до використання моделей нечіткої логіки 2-го типу та simulink-моделей у майбутніх дослідженнях. Це відкриває перспективи для подальшого розвитку та удосконалення методології очищення стічних вод у мийній промисловості. Очищення стічних вод є важливою задачею для збереження довкілля та забезпечення питної води. Використання нейронних мереж у методології очищення стічних вод може привести до подальшого розвитку та удосконалення процесу. Ось кілька напрямків, які можна розглянути для досягнення цих цілей: прогнозування якості стічних вод на основі вхідних параметрів, таких як концентрація речовин, температура, pH тощо; оптимізація різних етапів процесу очищення стічних вод, таких як фізико-хімічне оброблення, біологічне очищення та фільтрація; виявлення аномалій у процесі очищення стічних вод.

References

1. UNESCO. 2022. *The United Nations World Water Development Report 2022: Groundwater: Making the invisible visible*. Paris: UNESCO. https://www.undp.org/publications/united-nations-world-water-development-report-2022-groundwater-making-invisible-visible
2. Filipchuk, V.L., Drevetskyi, V.V., Filipchuk, L.V., Klepach, M.I. 2017. *Automated management of environmental protection systems for the treatment of metal-containing wastewater*. Rivne: NUVHP. http://surl.li/jjwew
3. Tymkiv, M.M. 2021. *Optimization of the well network of the hydrogeoecological monitoring system (on the example of the Pripyat River basin).* Kyiv: Institute of Environmental Geochemistry of the National Academy of Sciences of Ukraine. https://www.igns.gov.ua/wp-content/uploads/2021/05/dysertatsiya_tymkiv.pdf
4. Shtepa, V.M. 2020. *Scientific and theoretical foundations of environmentally safe industrial wastewater treatment technologies*. Sumy: Sumy State University. https://essuir.sumdu.edu.ua/handle/123456789/78079
5. Predzymirska, L.M. 2015. *Cavitation purification of natural and waste waters from organic and biological contaminants*. Lviv: Lviv Polytechnic National University. http://elar.nung.edu.ua/bitstream/123456789/8976/1/an2520.pdf
6. Xie, Y., Chen, Y., Lian, Q., Yin, H., Peng, J., Sheng, M., Wang, Y. 2022. Enhancing real-time prediction of effluent water quality of wastewater treatment plant based on improved feedforward neural network coupled with optimization algorithm. *Water*, 14(7), 1053. https://doi.org/10.3390/w14071053
7. Kumari, U., Swamy, K., Gupta, A., Karri, R.R., Meikap, B.Ch. 2021. Global water challenge and future perspective. In: *Green Technologies for the Defluoridation of Water* (pp. 197-212). London: Elsevier. https://doi.org/10.1016/B978-0-323-85768-0.00002-6
8. Tzanakakis, V.A., Paranychianakis, N.V., Angelakis, A.N. 2020. Water supply and water scarcity. *Water*, 12(9), 2347. https://doi.org/10.3390/w12092347
9. Thongam, D.D., Chaturvedi, H. 2021. Nanomaterials for climate change and water pollution mitigation. In: *Water Conservation in the Era of Global*

Climate Change (pp. 277-314). London: Elsevier. https://doi.org/10.1016/B978-0-12-820200-5.00005-1

10. Akpor, O.B., Otohinoyi, D.A., Olaolu, T.D., Aderiye, B.I. 2014. Pollutants in wastewater effluents: impacts and remediation processes. *International Journal of Environmental Research and Earth Science*, 3(3), 50-59. http://eprints.lmu.edu.ng/1023/1/IJERES_2014.pdf

11. Elsayed, A., Siam, A., El-Dakhakhni, W. 2022. Machine learning classification algorithms for inadequate wastewater treatment risk mitigation. *Process Safety and Environmental Protection*, 159, 1224-1235. https://doi.org/10.1016/j.psep.2022.01.065

12. Tarafdar, A., Shahi, N.Ch., Singh, A., Sirohi, R. 2018. Artificial neural network modeling of water activity: a low energy approach to freeze drying. *Food and Bioprocess Technology*, 11(1), 164-171. https://doi.org/10.1007/s11947-017-2002-4

13. Xinyi, Q. 2023. The application of artificial intelligence – artificial neural networks – in wastewater treatment. *E3S Web of Conferences*, 393, 03003. https://doi.org/10.1051/e3sconf/202339303003

14. Yadav, A., Chithaluru, P., Singh, A., Joshi, D., Elkamchouchi, D.H., Pérez-Oleaga, C.M., Anand, D. 2023. An enhanced feed-forward back propagation Levenberg–Marquardt algorithm for suspended sediment yield modeling. *Water*, 14(22), 3714. https://doi.org/10.3390/w14223714

15. Ali, S., Riaz, Sh., Safoora, Xiangryong, L., Wang, G. 2023. A Levenberg-Marquardt based neural network for short-term load forecasting. *Computers, Materials and Continua*, 75(1), 1783-1800. https://doi.org/10.32604/cmc.2023.035736

16. Malekian, A., Chitsaz, N. 2021. Concepts, procedures, and applications of artificial neural network models in streamflow forecasting. In: *Advances in Streamflow Forecasting* (pp. 115-147). London: Elsevier. https://doi.org/10.1016/B978-0-12-820673-7.00003-2

17. Le, T.H., Dai, L., Jang, H., Shin, S. 2022. Robust process parameter design methodology: A new estimation approach by using feed-forward neural network structures and machine learning algorithms. *Applied Sciences*, 12(6), 2904. https://doi.org/10.3390/app12062904

18. Jana, D.K., Bhunia, P., Adhikary, S.D., Bej, B. 2022. Optimization of effluents using artificial neural network and support vector regression in detergent industrial wastewater treatment. *Cleaner Chemical Engineering*, 3, 100039. https://doi.org/10.1016/j.clce.2022.100039

19. Sharma, K. 2022. *A comparative study of different technologies of sewage treatment plant*. Delhi: Delhi Technological University. http://dspace.dtu.ac.in:8080/jspui/bitstream/repository/19613/1/KESHAV%20SHARMA%20M.Tech.pdf

20. Singh, N.D., Murugamani, C., Kshirsagar, P., Tirth, V., Islam, S., Qaiyum, S., Suneela, B., Duhayyim, M.A., Waji, Y.A. 2022. IOT based smart wastewater treatment model for industry 4.0 using artificial intelligence. *Scientific Programming*, 2022, 5134013. https://doi.org/10.1155/2022/5134013

21. Pezhhanfar, S., Zarei, M., Shekaari, T., Khalilzadeh, M. 2021. Neural network, isotherm, and kinetic study for wastewater treatment using *populus alba*'s pruned material. *Iranian Journal of Chemistry & Chemical Engineering*, 40(6), 1868-1881. https://doi.org/10.30492/IJCCE.2020.43472

22. Yang, B., Xiao, Z., Meng, Q., Yuan, Y., Wang, W., Wang, H., Wang, Y., Feng, X. 2023. Deep learning-based prediction of effluent quality of a constructed wetland. *Environmental Science and Ecotechnology*, 13, 100207. https://doi.org/10.1016/j.ese.2022.100207.

The article has been sent to the editors 11.08.23.
After processing 15.08.23.
Submitted for printing 20.08.23.